



| | |
|------------------|---|
| Title | 合成開口レーダを利用した圃場情報の取得に関する研究 [全文の要約] |
| Author(s) | 山谷, 祐貴 |
| Citation | 北海道大学. 博士(農学) 甲第14374号 |
| Issue Date | 2021-03-25 |
| Doc URL | http://hdl.handle.net/2115/84519 |
| Type | theses (doctoral - abstract of entire text) |
| Note | この博士論文全文の閲覧方法については、以下のサイトをご参照ください。 |
| Note(URL) | https://www.lib.hokudai.ac.jp/dissertations/copy-guides/ |
| File Information | Yamaya_Yuki_summary.pdf |



[Instructions for use](#)

博士論文の要約

博士の専攻分野の名称： 博士（農学）

氏名 山谷 祐 貴

学位論文題名

合成開口レーダを利用した圃場情報の取得に関する研究

圃場ごとの作物に関する情報（圃場情報）は、作目ごとの作付面積の調査、生産量の予測、生育状態の把握、災害発生時の被害調査など、様々な用途に供せられており、今後も継続的かつ長期的、広域的に把握していくことが重要である。例えば農林水産省では、作物統計調査として職員や統計調査員による耕地面積および作付面積の実測調査が行われている（農林水産省、2020）。しかし、現在人の手によって行われている現地調査は、人手不足により調査が縮小される懸念もあり、作付状況に関する情報の十分な把握が、今後は困難となるおそれがある。したがって、人的コストの削減を進める一方で、圃場ごとの作物に関する情報を詳細に把握していく手法の確立が必要であり、これらの両立が日本の農業地域における課題の一つとなっている。

また、地球観測戦略における課題として、食料の収穫状況や収量を効果的かつ継続的に監視することが挙げられており、これら農業生産に関する情報は先進国、発展途上国ともに今後重要視されていくと考えられる（辻野、2014）。すなわち、農業に関する情報を広範囲かつ効率的に取得することは、農業分野全体の産業競争力強化をもたらすための課題となると考えられる（高度情報通信ネットワーク社会推進戦略本部、2014）。

これらの課題の解決策として、従来の現地調査に代わる手法の確立が不可欠である。その中でも衛星リモートセンシング技術は、農業分野において対象物の状態を非破壊で計測する手法として期待されており（齋藤ら、2017）、作付品目の特定や作付面積の把握、作物生育の把握などにますます利用されることが期待されている（野口、2016）。したがって、衛星観測データの効率的な利用は農業分野において特に有望な情報収集手段の一つになりうる。

本論文は全8章で構成される。序章では、農業地域での圃場情報取得に関する課題およびリモートセンシングの農業利用に関する既往研究について総括した。また、SARにおける農業利用の有効性と、後方散乱係数や散乱成分の算出方法と必要性についても解説した。

リモートセンシングはこれまで様々な分野で用いられてきており、農業分野においてもその利用が注目されつつある。リモートセンシングの中でも、可視光から赤外線にかけての波長を利用した受動型センサ（光学センサ）を用いて、作付作物を分類する研究や作物のバイオマス量を推定する研究は数多くなされてきた。しかし、光学センサによる観測データでは、大気による減衰

が多く、特に煙霧や雲などの影響を受けやすいとされている。そのため、天候によっては作物分類や生育推定の精度が大幅に低下するおそれがあり、使用できる衛星データの数に限られてしまう可能性がある (Blaes *et al.*, 2005)。また光学センサのうち、可視光や近赤外など短波長の電磁波を受動型センサで測定する場合、暗所や夜間では微弱な放射源の下での測定になるため困難となる (McNairn *et al.*, 2002)。

光学センサに対して、マイクロ波を利用したセンサも存在しており、特に能動型センサによるものは合成開口レーダ (SAR, Synthetic Aperture Radar) と呼ばれている。能動型センサは自身で照射した電磁波を観測するため、受動型センサのように太陽光などを必要としない。そのため、昼夜を問わず安定した観測が可能である。またマイクロ波センサは、光学センサと異なり大気による減衰が少なく、大気や天候に影響をほぼ受けることなくデータを取得することが可能である (Bindlish and Barros, 2001; Mascolo *et al.*, 2019) という特長もある。したがって、SAR データを用いた作付や生育の状況に関する情報把握は、光学センサと比較しても汎用性、堅牢性が非常に高く、毎年安定して確実にデータを得られる手法であることから (石塚, 2016)、特に多時期のデータを使用する作付作物分類や生育状況推定には効果的であると考えられる。

以上を踏まえ、SAR により取得された衛星データの各変数を中心に使用し、圃場情報を高精度かつ効率的に取得することを研究の目的として挙げた。特に作付作物の分類および水稻穂含水率の推定を行い、農業分野における SAR の有望な情報収集手段として適用することの可能性を評価することとした。

2 章では、X バンドの SAR を搭載した TerraSAR-X が観測した 2 偏波データを使用し、衛星データにおける作付作物分類の可能性について検討を行った。SAR データは、6 月から 7 月にかけて 11 日毎に観測された計 5 時期を使用した。変数の算出には、SAR データから算出される主要な変数である HH, VV 偏波の後方散乱係数 2 要素 (σ^{0}_{HH} , σ^{0}_{VV}) だけでなく、固有値解析法 (Cloude, 2007) によって算出される散乱成分の 2 要素 (エントロピ, アルファ角) も使用した。分類アルゴリズムには、パターン認識の手法を用いて高い精度が期待できる機械学習アルゴリズムの Random Forests (Breiman, 2001) を使用した。対象地域は北海道の十勝地方であり、当地における代表的な 6 作物 (小麦, 豆類, 馬鈴薯, 甜菜, 牧草, トウモロコシ) の 5,057 圃場を対象圃場とした。分類を実行するにあたり、対象地域における圃場境界 GIS データから、変数ごとに平均値を圃場単位で抽出し、圃場ポリゴン単位での分類を実施した。圃場のうち 20% を教師データとして分類モデルを作成し、残りの 80% の圃場をテストデータとして精度評価に使用した。

まず、5 時期分の衛星データとそれぞれから得られる 4 要素をすべて用いた 20 変数で作付作物の分類を行い、精度を評価した。その結果、5 時期 4 要素すべてを用いた場合、0.90 の全体精度を得ることができた。分類に寄与した変数を確認するため、各変数のジニ係数減少量を算出した結果、各後方散乱係数の方が特に本結果に寄与していることが示された。さらに時期別に見ると、7/9 のデータの重要度が最も高く、次いでその前後である 6/28 や 7/20 のデータの要素が本結果に寄与していることが示された。

使用する時期数は少なければ少ないほど、衛星データの取得に費やすコストをより下げること

ができ、要素数も不要なものは省略した方が簡単に分類できる。したがって、次にこれらの時期数や要素数を削減したうえで分類することにより、高い分類の精度を維持することが可能であるかについても検討した。その結果、要素数を削減すると精度は大きく下がり、高精度の維持は望めないことが確認された。一方、時期数を削減した場合でもある程度高い精度を維持することが可能であった。とくに 6/28 と 7/9 を含む 2 時期以上のデータ数があれば全体精度が 0.8 を上回り、4 時期以上あれば 5 時期と有意差のない結果（全体精度 0.89）が得られ、より低コストでの作物分類が可能となると結論づけた。

3 章では、C バンドの SAR を搭載した RADARSAT-2 が観測した 4 偏波データを使用し、C バンドデータのみ、C バンドおよび X バンドデータの併用から、更に高精度な作付作物の分類を目指して検討を行った。SAR データは、5 月から 8 月にかけて 24 日毎に観測された計 5 時期の C バンドデータと、このデータに近い時期に観測があった計 5 時期の X バンドデータを使用した。変数の算出は、C バンドからは HH, HV, VV 偏波の後方散乱係数 3 要素 (σ^{0HH} , σ^{0HV} , σ^{0VV}) と、固有値解析法 (Cloude and Pottier, 1996) によって算出される散乱成分の 3 要素 (エントロピ, アニソトロピ, アルファ角) のほか、散乱モデル分解法のうち Freeman-Durden 法 (Freeman and Durden, 1998), van Zyl 法 (van Zyl *et al.*, 2011), Yamaguchi 法 (Yamaguchi *et al.*, 2005) の 3 種類の手法から算出される散乱成分 3 要素 (表面散乱, 2 回散乱, 体積散乱, Yamaguchi 法のみヘリックス散乱を加えた 4 要素) の計 16 要素とした。X バンドからは前章と同様の 4 要素を算出した。分類アルゴリズムには、前章と同様に Random Forests を使用し、圃場ポリゴン単位での分類を実施した。

まず、C バンドデータのみを使用し、作付作物の分類を行った。その結果、5 時期 16 要素 (計 80 変数) のデータを使用することにより、圃場の作付作物を 0.9 以上の高い全体精度で分類がなされた。この結果は、2 章で示した X バンドデータのみを使用した分類結果よりも高い精度であり、C バンドデータを使用して作付作物の分類を行うことの有効性が示された。また、後方散乱係数、固有値解析法、van Zyl 散乱モデル分解法の 3 データセットから算出される 5 時期 9 要素 (計 45 変数) のみで分類を行うことにより、5 データセットすべてを用いた分類よりも精度の高い 0.92 の全体精度が得られた。以上より、5 時期の C バンドデータを用いて作付作物の分類を行うにあたっては、複数の散乱モデル分解法を併用する必要はなく、上記 3 データセットを用いることが最も有効であるといえる。

次に、C バンドデータおよび X バンドデータを併用し、作付作物の分類を行った。C バンドデータからは上記 3 データセットの 9 要素を、X バンドデータからは後方散乱係数と固有値解析法の 4 要素を用いて分類を行い、精度を比較した。その結果、全体精度は 0.93 となり、C バンドデータのみを使用した場合と比較して有意差のある結果が得られた。以上より、5 時期の C バンド 4 偏波衛星データおよび X バンド 2 偏波衛星データを併用して作付作物の分類を行うにあたっては、前者からは後方散乱係数、固有値解析法、van Zyl 散乱モデル分解法の計 9 要素を、後者からは後方散乱係数、固有値解析法の計 4 要素をそれぞれ算出して用いることが最も有効であるといえる。この手法では、いずれか一方のバンドの衛星データを使用した場合よりも高い全体精度で

分類可能であったことから、波長が違う衛星データを組み合わせることにより補完され精度が上がったと考えられる。

最後に、Cバンドデータを使用した分類と、CバンドデータおよびXバンドデータを併用した分類のそれぞれの結果について、5 時期すべての衛星データを使用しなくても、同様の高精度な分類が可能であるか検討した。Cバンドデータによる分類では、3 時期以上を使用することで0.9を超える全体精度が得られ、4 時期のデータを使用すると5 時期のデータを使用した場合と有意な差のない結果が得られた。CバンドデータおよびXバンドデータを併用した分類では、各2 時期以上を使用することで0.9を超える全体精度が得られ、3 時期のデータを使用すると5 時期のデータを使用した場合と有意な差のない結果が得られ(全体精度0.93)、より低コストでの作物分類が可能となると結論づけた。Cバンド、Xバンドデータを併用した分類では、3 時期の使用で5 時期と同様の精度になったが、ここで使用するデータの3 時期の目安として、次に示すものを使用することで特に高い精度となる。1) 小麦出穂後、豆類出芽後、馬鈴薯開花前後、牧草1 番草収穫後。本地域では6 月下旬。2) 小麦登熟前後、馬鈴薯開花後、牧草2 番草収穫後。本地域では7 月中旬。3) 小麦収穫前後、豆類開花後、トウモロコシ出穂後。本地域では8 月上旬。また、圃場ポリゴンの大きさが10a 以下の圃場では誤分類が生じやすく、狭小な圃場での分類は困難であるといえ、注意が必要である。逆に、1.5ha 以上の圃場であれば、0.95 以上の全体精度で分類を行うことができることを確認した。

4 章では、SAR による作付作物分類で使用された例がない2 種類の機械学習アルゴリズムをRandom Forests と比較し、CバンドとXバンドを併用した分類の精度向上を検討した。SAR データは2 年間にわたって取得し、1 年目は前章と同様の各バンド5 時期、2 年目は6 月から9 月にかけて観測された各6 時期のCバンド、Xバンドデータを使用した。Cバンドデータの観測周期は24 日と長いため、2 年目は2 種類の入射角のCバンドデータを併用し、観測するタイミングを増やすこととした。変数の算出は、Cバンドからは前章で最も良好な精度が得られた後方散乱係数、固有値解析法、van Zyl 散乱モデル分解法の計9 要素とした。Xバンドからは、後方散乱係数、固有値解析法のほか、2 偏波のための散乱モデル分解法(Raney, 2013) から3 要素(表面散乱, 2 回散乱, 体積散乱)を算出し、計7 要素とした。分類アルゴリズムには、Random Forests のほか、Extremely Randomized Trees (Geurts *et al.*, 2006) および Random Ferns (Ozuysal *et al.*, 2010) を使用した。これらの分類アルゴリズムは、他分野の研究や光学センサによる作付作物分類で有用な結果を示した報告がなされている (Kim *et al.*, 2019)。しかし、SAR データによる作付作物分類でこれらの分類アルゴリズムが使用された例がないため、圃場ポリゴン単位での分類結果から、Random Forests との精度を比較することとした。

まず、決定木を用いた3 種類の分類手法について、使用する教師データの比率や時期数の条件を変更し、精度を比較した。その結果、Extremely Randomized Trees はすべての条件で他の分類アルゴリズムより全体精度が高かった。また、2 時期のデータのみを使用した Extremely Randomized Trees での分類は、5 時期のデータを使用した Random Forests での分類と有意差がない精度となった。以上の結果から、SAR を用いた多時期の作付作物分類において、Extremely

Randomized Trees が特に有効な分類アルゴリズムであると結論づけた。

次に、この Extremely Randomized Trees を適用し、X バンド SAR データと C バンド SAR データのどちらで高い精度を得られるか、時期や時期数を変更し比較を行った。その結果、1 時期による分類では、7 月までは C バンドデータの方が概ね高い全体精度が得られ、8 月は X バンドの方が高い全体精度となる傾向がみられた。多時期での分類では、C バンドデータの方が X バンドデータと比較してほぼすべて高い全体精度となり、多時期の作付作物分類に有効なバンドであることを示した。これは、生育ステージ初期における C バンドデータの変数が分類に寄与したためであると考えられる。以上より、多時期の作付作物の分類をいずれかのバンドで行う場合においては、C バンドデータの方が有効であると結論づけた。

最後に、これらの結果を踏まえ、使用する衛星データの利用コストを抑制するため、衛星データの選択方法を検討した。7 月上旬までの C バンドデータ 2 時期と 7 月中旬以降の X バンドデータ 4 時期を併用することで、0.95 を超える全体精度が得られた。これは、両バンドの 6 時期（計 12 時期）をすべて使用した分類と比較して有意差がなかった。以上のように、双方のバンドを用いる場合には、7 月中旬で C バンドから X バンドに衛星データを切り替える手法が、衛星データの利用コストを大幅に減少させつつ高い精度を得られるものとして期待される。この手法は、本研究の成果による新たな衛星データの選定法として提示されるものである。

5 章では、C バンドや X バンドの SAR データと比較して安価に利用できる、L バンドの SAR を搭載した PALSAR-2 のデータを使用し、波長間での精度の比較や、取得コストを削減した作付作物の分類手法について提示した。研究は 2 年分のデータを用いて実施し、C バンドは前章と同様の 1 年目 5 時期、2 年目 6 時期のデータを使用した。L バンドは 1 年目に 4 偏波データを 2 時期、2 年目に単偏波データを 2 時期、4 偏波データを 1 時期、それぞれアーカイブ画像から取得し、各年で分類を実施した。変数の算出は、C、L バンドの 4 偏波データからは前章と同様に後方散乱係数、固有値解析法、van Zyl 散乱モデル分解法の計 9 要素とした。分類アルゴリズムには、3 章と同様に Random Forests を使用し、圃場ポリゴン単位での分類を実施した。

まず、1 年目の 8 月上旬に観測された L バンド、C バンドデータのそれぞれで、1 時期の 4 偏波データで分類を行い、両者の精度を比較した。その結果、C バンドデータの方が高い全体精度を得られた。いっぽう、L バンドデータからは良好な全体精度を得られず両者に有意差がみられた。しかし、両者を併用することにより全体精度は向上し、C バンドデータのみを使用した分類と比較して有意差がみられた。以上より、1 時期の後方散乱係数や散乱成分の 9 変数を使用した作付作物分類では、C バンドデータの方が良好な精度が得られるが、C バンド、L バンドデータを併用することにより、各バンドが地表面の状態に対して異なる散乱をするために、情報を補完し合うことで精度の向上が期待できることから、併用することの有効性が示された。

次に、各バンドで観測されたデータのうち複数の時期のものを使用し、分類結果の比較を行った。1 年目の結果については、C バンドデータでは 0.9 を超える全体精度を得られたのに対し、L バンドデータでは 0.5 を下回る結果となった。また、両者を併用した分類でも、C バンドデータのみを使用した分類と同等の精度であった。ただし、1 年目の条件下では、L バンドデータを 8 月

以降の 2 時期しか使用していない。すなわち、両者を比較するにあたり、L バンドデータが不足していたことも高い精度が得られなかった原因であると考えられる。そこで 2 年目については、6 月に観測された単偏波の L バンドデータ 2 時期を取得し、8 月の 4 偏波データと併せて計 3 時期のデータで分類を行い、精度の向上や効率化を検討した。また、C バンドデータも、L バンドで観測されたデータの時期に近い 3 時期のみを使用し、条件を近づけて比較した。その結果、C バンドデータによる分類の方が精度は高かったが、L バンドデータについても、1 年目の結果より大幅な精度の向上がみられた。しかし、両者を併用した分類では C バンドデータのみを使用した分類と有意差はみられなかった。以上の点から、多時期による分類では、C バンドデータでの分類の方が作付作物分類には有効であると結論づけた。

最後に、C バンドデータをできるだけ使用せず、L バンドデータで代替することが可能であるかに注目して検討した。まず、6 時期の C バンドデータのうち、いくつかの時期を L バンドデータで代替する手法を実行した。その結果、C バンドデータのうち 1 時期を L バンドデータに変更しても有意差のない精度が得られた。2 時期を L バンドデータに変更すると有意差がみられたが、6 月の 1 時期と 8 月の 1 時期を L バンドデータに変更しても 0.9 を超える全体精度が得られた。次に、2~3 時期の C バンドデータに 1~2 時期の L バンドデータを加える手法を実行したところ、L バンドデータのみを使用した分類と比較して大幅に精度の向上がみられた。とくに 7 月上旬までの C バンドデータを 1~2 時期加えて分類することにより、効率的に高い精度を得ることができた。以上より、2 時期の L バンドデータと、6 月のデータを含めた 4 時期の C バンドデータを併用することにより、0.9 を超える精度で分類を行うことができ、2 章で示した X バンドデータによる分類よりも高精度であったことから、取得コストを削減した効率的な分類を達成できると結論づけた。また、L バンドデータを中心とした分類では、2 時期の L バンドデータに 6 月や 7 月上旬の C バンドデータを 2 時期追加することで、少ないシーン数でも高い精度を得られることから、実用的に L バンドデータを分類に使用する方法となりうることが示された。

6 章では、C バンドの SAR を搭載した RADARSAT-2 に加えて、高解像度光学センサである Geoeye-1 データを併用し、水稻の穂含水率を推定するモデルの作成と検証を行った。対象地域は北海道の空知地方であり、対象作物は本地域の代表的な作物である水稻とし、各年とも 11~13 圃場を対象圃場に選定した。水稻には移植栽培の圃場と直播栽培の圃場が含まれる。SAR データは、8 月から 9 月にかけて観測された 4 年分のデータ計 7 時期を使用し、前章と同様に 9 変数を算出した。光学センサデータは、SAR データの観測時期に近い 1 時期のデータを使用し、NDVI を算出した。また、モデルの目的変数である穂含水率は、SAR データの観測時期に合わせて 7 時期とも現地調査を行い、各圃場内に 3 か所に対象区画を設置し、刈り取りを行った。刈り取った穂は乾燥機に入れ、乾燥前後の質量変化から含水率を計算し、圃場の含水率の値とした。SAR データおよび光学センサデータの変数を説明変数として、ステップワイズの変数減少法を用いた重回帰分析を使用し、モデルの作成を行った。モデル作成にあたり、対象圃場の圃場境界 GIS データを作成し、SAR や光学センサの各変数で圃場単位の平均値を抽出し、圃場ポリゴン単位でモデル作成を実施した。

まず、SAR データのみを使用した推定モデルの作成を行った。1 年目から 3 年目までの計 5 時期の SAR データを使用して、9 変数から推定モデルを作成したところ、決定係数は 0.152 となり、高い精度を得られなかった。実測値が高い圃場では推定値が低く、過小評価されている傾向がみられ、実測値が低い圃場では推定値が高く、過大評価されている傾向がみられた。

そこで、これら 5 時期の SAR データのうち、アセンディング軌道で観測された SAR データまたはディセンディング軌道で観測された SAR データのいずれかのみを使用し、衛星進行方向ごとに推定モデルを作成した。その結果、それぞれのモデルで全データモデルよりも高い決定係数が得られた。とくにアセンディング軌道によるモデルでは決定係数が 0.6 を上回り、精度の向上がみられた。この結果から、モデルの作成には衛星進行方向ごとにデータを分割することで、より精度の向上が期待できることが示された。この原因として、ディセンディング軌道の観測時間が早朝であり、水稻の表面の水分の影響を受けやすい点などが精度の低下を招く原因として考えられる。したがって、衛星進行方向や観測時間は重要な条件となる可能性が示唆された。

また、これら 5 時期の SAR データを用いて、直播栽培と移植栽培の圃場でそれぞれ分割し、栽培形態ごとのモデルを作成した。その結果、いずれのモデルも全データから作成したモデルよりも高い精度が得られた。特に移植栽培のモデルでは決定係数が 0.5 を上回った。この結果から、衛星進行方向だけでなく栽培形態も考慮に入れることにより、モデルの精度の向上が期待できることが示された。以上の結果から、SAR データから水稻の穂含水率を推定するためには、衛星進行方向をアセンディング軌道に固定したうえでモデルを作成すると、良好な精度を得られることが示唆された。また、観測時期の都合によりディセンディング軌道のデータを使用するとしても、直播栽培と移植栽培の区別を行ってモデルを作成することにより、良好な精度で穂含水率を推定できる可能性も示唆された。なお、ほぼすべてのモデルでエントロピが変数として選択されていたため、特に水稻の穂含水率との間に関係性が深い変数であることが示された。

つづいて、SAR データと光学センサデータを併用した推定モデルの作成を行った。まず 1 時期の光学センサデータのみを使用して、NDVI から推定モデルを作成したところ、高い決定係数が得られなかった。しかし、1 点の外れ値を除くことで精度の向上がみられた。この 1 圃場は他の圃場と異なり、湛水されていたことから、光学センサのみを使用したモデルにおいては湛水の有無が精度を左右する可能性が示唆された。そこで、SAR データと光学センサ 1 データを併用してモデルの作成を行ったところ、決定係数は 0.9 を超え、精度の向上がみられた。この結果から、両者を併用することで、湛水の有無の影響を減らすことができ、精度の向上に効果があると考えられる。したがって、水稻の穂含水率を推定するためには、SAR データと光学センサデータを併用することが最も良好な方法であると結論づけた。しかし、本地域は夏季に曇天となることが多く、対象とした 4 年間でも 1 時期しか光学センサデータを取得できなかったことから、先述の SAR データのみによるモデルを有効に活用することが期待される。また、本章でも光学センサデータが少なかったことから、他の時期にも同様の精度が得られるかは不明であり、今後もデータを取得してモデルの改良に努めることも必要となる。

最後に、2016 年から 2018 年までの 5 時期の SAR データから作成した 5 つのモデルについて、2019 年の 2 時期の SAR データを用いた精度の検証を行った。過去年のデータを用いて作成した

モデルを翌年のデータで検証することにより、今後このモデルを使用していくことが可能であるか検討することができる。その結果、全データモデルについては RMSE が 6%程度となり、良好な精度を得ることができた。全データモデルは作成した際の決定係数は低かったが、様々な時期や条件の情報が含まれていたことから、別の年のデータにも良好な適合がなされたと考えられる。条件ごとに分割したモデルの検証では、直播栽培で RMSE が 4%以下の良好な結果が得られた。一方、他の 3 つのモデルは全て RMSE が 10%を上回り、全データを用いたモデルと比較して良好な結果を得ることができなかった。その理由として、ディセンディング軌道によるモデルは作成した時点で精度が低かったことから、検証においても高い精度が得られなかったと考えられる。先述のとおり、ディセンディングは水稻の水分付着が影響している可能性があり、モデルに対応しにくい点が問題として挙げられる。また、2019 年のアセンディング軌道のデータに関しては、入射角がモデルを作成した際に使用したデータより約 10°大きいデータであったことが要因として考えられる。したがって、衛星進行方向（観測時間）や栽培形態だけでなく、入射角についてもモデルの情報に取り入れる必要があると考えられる。移植栽培と直播栽培のモデルで検証の精度が大きく異なっていたことから、特に移植栽培の圃場ではこれら入射角や水分付着などの影響を受けやすい可能性が示唆される。以上の結果から、SAR と光学センサを併用したモデルは最も高い精度が得られる可能性がある一方で、光学センサが観測できない場合に SAR のみでもある程度良好なモデルを作成できることが示された。とくに直播栽培の圃場のみを対象としたモデルについては汎用性が高く有効であった。移植栽培の圃場においても、入射角が 30° 程度のアセンディング軌道で観測されたモデルであれば、ある程度の精度が得られる可能性が示された。

7 章では、C バンド SAR データの 9 変数に加えて、3 種類のダミー変数（衛星進行方向、衛星入射角、栽培形態）を使用し、圃場単位での水稻の穂含水率を推定するモデルを作成した。モデル作成には、前章と同様にステップワイズの変数減少法を用いた重回帰分析を用いて、圃場単位でモデル作成を実施した。衛星進行方向、入射角、栽培形態の各情報をダミー変数としてモデルの説明変数に使用することにより、1 つで全てのデータや圃場に対応したモデルを作成するとともに、精度を向上させることを目指した。

まず、4 年間の全 7 時期の SAR データから 9 変数を算出し、ダミー変数を使用せず、重回帰分析により推定モデルの作成を行った。その結果、決定係数は低く、良好な精度を得られなかった。この結果を基準として、様々な条件で作成したモデルの精度について評価した。4 年間の SAR データのうち、アセンディング軌道で観測されたデータを使用したモデルと、ディセンディング軌道で観測されたデータを使用したモデルを作成した。これらのモデルには、SAR データの 9 変数に加えて、入射角と栽培形態を示す各ダミー変数を追加し、精度を比較した。その結果、双方のモデルともダミー変数を加えることにより、決定係数が向上した。とくにダミー変数を加えた場合は、アセンディング軌道のモデルで決定係数が 0.6 を上回り、高い精度が得られた。ダミー変数には双方のモデルとも栽培形態が選択されており、栽培形態の付加情報によって水稻の穂含水率がより高い精度で推定されることを示した。

次に、4 年間の SAR データのうち、直播栽培の圃場のデータのみを使用したモデルと、移植

栽培の圃場のみを使用したモデルを作成した。これらのモデルには、SAR データの 9 変数に加えて、衛星進行方向と入射角を示す各ダミー変数を追加し、精度を比較した。その結果、直播栽培、移植栽培とも、モデルはダミー変数を加えても決定係数の向上がみられず、いずれも 0.3 程度の決定係数しか得られなかった。

最後のモデルの作成として、4 年間の SAR データのうち、SAR データから算出された 9 変数と、全 3 種類のダミー変数のすべてを使用してモデルを作成した。その結果、決定係数は 0.452、RMSE は 6.48%と、ダミー変数を使用していないモデルと比較して精度が向上した。ダミー変数を使用することにより、これまでみられていた過大評価や過小評価の傾向が緩和された。この結果は、ダミー変数を含めたアセンディング軌道によるモデルと比較して精度は低いものの、先述の他の 3 種類のモデルと比較すると高い精度が得られた。以上の結果より、水稻の穂含水率を推定するモデルを作成するにあたり、ダミー変数の有効性が示された点や、ダミー変数を使用することでモデルを分割する必要性が低くなった点から、全データにダミー変数を加えたモデルが最も有効な水稻の穂含水率の推定モデルであると考えられる。

この全データにダミー変数を加えたモデルについて、交差検証を行った。交差検証には、5 分割による検証手法を用いた。交差検証は、先述の全データにダミー変数を加えたモデルにおいて、説明変数に選択された 4 変数を使用したモデル（ダミー変数あり 4 変数モデル）と、すべての変数で再度ステップワイズをし直したダミー変数あり再構築モデル、ダミー変数を使用していないダミー変数なしモデルの 3 種類で行った。その結果、検証結果における RMSE の平均はダミー変数あり 4 変数モデルが最も低く、良好な精度となった。以上の結果より、4 変数を使用したモデルは汎化性能が高く、最も有効なモデルであると結論づけた。

終章では、各章の総括と本研究全体の総括を行った。SAR により取得された衛星データは、畑作地帯における作付作物の分類や、稲作地帯における水稻の穂含水率の推定について、高い精度での適用が可能であった。作付作物の分類では、7 月上旬までの C バンド SAR と 7 月中旬以降の X バンド SAR を併用し、各データから後方散乱係数、散乱モデル分解法による散乱成分、固有値解析法による散乱成分を算出して、ERT のアルゴリズムへ適用することが特に有効であることが明らかとなった。水稻の穂含水率の推定では、8 月下旬の C バンド SAR を使用し、栽培体系のダミー変数を用いた 4 変数モデルを使用することで、有効な重回帰モデルを作成できることを示した。これらの結果から、合成開口レーダは農業分野において圃場の情報を取得するための有望な手段となることが結論づけられた。

参考文献

- Bindlish, R. and A. P. Barros. (2001) Parameterization of vegetation backscatter in radar-based, soil moisture estimation. *Remote Sensing of Environment*, **76**, pp.130-137.
- Blaes, X., L. Vanhalle and P. Defourny. (2005) Efficiency of crop identification based on optical and SAR image time series. *Remote Sensing of Environment*, **96** (3-4), pp. 352-365.
- Breiman, L. (2001) Random forests. *Machine Learning*, **45** (1), pp. 5-32.

- Cloude, S. R. (2007) The dual-polarization entropy/alpha decomposition: a pulsar case study, *Proc. POLInSAR*, Frascati, Italy, pp. 1-6.
- Cloude, S. R. and Pottier, E. (1996) A review of target decomposition theorems in radar polarimetry. *IEEE Transactions on Geoscience and Remote Sensing*, **34** (2), pp. 498-518.
- Freeman, A. and Durden, S. L. (1998) A three-component scattering model for polarimetric SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, **36** (3), pp. 963-973.
- Geurts, P., Ernst, D. and Wehenke, L. (2006) Extremely randomized trees. *Machine learning*, **63** (1), pp. 3-42.
- 石塚直樹 (2016) マイクロ波合成開口レーダを用いた農地計測事例. 計測と制御, **55** (9), pp. 814-817.
- Kim, N., Ha, K. J., Park, N. W., Cho, J., Hong, S. and Lee, Y. W. (2019) A Comparison Between Major Artificial Intelligence Models for Crop Yield Prediction: Case Study of the Midwestern United States, 2006-2015. *ISPRS International Journal of Geo-Information*, **8** (5), 240.
- 高度情報通信ネットワーク社会推進戦略本部 (2014) 農業情報創成・流通促進戦略.
<http://www.kantei.go.jp/jp/singi/it2/kettei/pdf/senryakuzenbun_140603.pdf>, 22/03/2020 referred.
- Mascolo, L., Forino, G., Nunziata, F., Pugliano, G. and Migliaccio, M. (2019) A New Methodology for Rice Area Monitoring With COSMO-SkyMed HH-VV PingPong Mode SAR Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **12** (4), pp. 1076-1084.
- McNairn, H., Ellis, J., Van Der Sanden, J. J., Hirose, T. and Brown, R. J. (2002) Providing crop information using RADARSAT-1 and satellite optical imagery. *International Journal of Remote Sensing*, **23** (5), pp. 851-870.
- 野口伸 (2016) ICT 農業とリモートセンシング. 日本ロボット学会誌, **34** (2), pp. 100-102.
- 農林水産省 (2020) 面積調査の概要.
<<https://www.maff.go.jp/j/tokei/kouhyou/sakumotu/menseki/gaiyou/index.html#1>>, 10/12/2020 referred.
- Ozuysal, M., Calonder, M., Lepetit, V. and Fua, P. (2010) Fast keypoint recognition using random ferns. *IEEE transactions on pattern analysis and machine intelligence*, **32** (3), pp. 448-461.
- Raney, R.K. (2013) M-Chi Decomposition of Imperfect Hybrid Dual-Polarimetric Radar Data. Proceedings of 6th International Workshop on Science and Applications of SAR Polarimetry and Polarimetric Interferometry: PolInSAR 2013.
- 齋藤元也, 石塚直樹, 坂本利弘 (2017) 日本における農業リモートセンシング研究の軌跡. 日本リモートセンシング学会誌, **37** (3), pp. 193-203.
- 辻野照久 (2014) 衛星画像を利用した農業生産統計. 科学技術動向, **145**, pp. 26-30.
- Van Zyl, J. J., Arii, M. and Kim, Y. (2011) Model-Based Decomposition of Polarimetric SAR Covariance Matrices Constrained for Nonnegative Eigenvalues. *IEEE Transactions on Geoscience and Remote Sensing*, **49** (9), pp. 3452-3459.
- Yamaguchi, Y., Moriyama, T., Ishido, M. and Yamada, H. (2005) Four-component scattering model for polarimetric SAR image decomposition. *IEEE Transactions on Geoscience and Remote Sensing*, **43** (8), pp. 1699-1706.